

北京化工大学

技术报告

题目：SGT 模型在磁信号异常检测中的应用及改进思路

姓　　名：胡 苏 杭

专　　业：计算机科学与技术

学　　院：信息科学与技术学院

二 〇 二 四 年 一 月 六 日

SGT 模型在磁信号异常检测中的应用及改进思路

摘 要

本报告探究了 SGT 模型在磁探领域的应用，特别关注了其在 MGT、SNR0 和 SNR5 数据集上的性能表现。实验结果揭示了 SGT 模型在处理这些数据集时存在虚警率过高和预测偏差较大等问题。为解决模型的预测能力和泛化能力不足的问题，我们设计了一系列改进实验，着重从调参、优化特征提取方式和修改连续性判断三个方面入手。

在这三种改进方法中，调参取得了约 0.5%的性能提升，特征提取优化和正交基判断的方法反而预测效果降低了 20%。通过代码审查和逻辑推理，我们发现问题源于特征提取与模型不兼容。为适应正交基算法，我们提出一种改进思路：引入多种不同类型的特征，包括时域特征、频域特征和统计特征等，并综合利用这些特征信息，构建更为复杂而全面的 SGT 模型。此外，引入 stacking 模块，将基于不同特征的单一模型的预测结果作为输入，通过进一步的学习和综合，生成更准确的预测。

关键词：SGT，磁探，多特征预测

APPLICATION AND IMPROVEMENT STRATEGIES OF THE SGT MODEL IN MAGNETIC SIGNAL ANOMALY DETECTION

ABSTRACT

This report explores the application of the SGT model in the field of magnetic prospecting, with a special focus on its performance on the MGT, SNR0 and SNR5 datasets. The experimental results reveal that the SGT model suffers from high false alarm rate and large prediction bias when dealing with these datasets. To address the insufficient predictive and generalization abilities of the model, we designed a series of improvement experiments focusing on three aspects, namely, tuning parameter, optimizing the feature extraction method and modifying the continuity judgment.

Among these three improvement methods, tuning parameter achieved about 0.5% performance improvement, and the methods of feature extraction optimization and orthogonal basis judgment instead reduced the prediction effect by 20%. Through code review and logical reasoning, we found that the problem stems from feature extraction incompatibility with the model. In order to adapt to the orthogonal basis algorithm, we propose an improvement idea: introduce many different types of features, including time-domain features, frequency-domain features, and statistical features, etc., and comprehensively utilize the information of these features to construct a more complex and comprehensive SGT model. In addition, the stacking module is introduced to take the prediction results of a single model based on different features as inputs, and generate a more accurate ultimate prediction through further learning and synthesis.

KEY WORDS: SGT, Magnetic Prospecting, Multi-feature Prediction

目录

一、引言

磁信号异常检测在地球科学和资源勘探领域中扮演着关键的角色，磁异常探测技术的难点是磁异常信号通常很微弱，容易受到地磁场的背景噪声、仪器噪声、电磁干扰等因素的干扰，因此需要对磁异常信号进行有效的特征提取、分类和检测。而 SGT 模型在 Vision Transformer 模型基础上，改进了 patch split 的构造结构，使得 Transformer 与 Shifted-Grad Block 相结合，增强了一维数据长距离依赖关系，在磁数据上表现出了良好效果，本文旨在深入探讨 SGT 模型[1]在磁信号检测中的具体应用，并简单论述从实际应用中发现的一些挑战与问题。

二、磁信号异常

2.1 磁信号异常基本概念

磁信号异常通常指地球磁场在某一区域或时段内发生异常性变化的现象。地球磁场是由地球内部流动的液态外核产生的，因此地球的磁场是动态且复杂的。磁信号异常可能是由地下的地质结构变化、矿产资源分布、地壳运动等引起的[2][3]。

在地球科学和勘探领域中，对磁信号异常的监测和分析具有重要价值。磁信号异常的探测有助于识别地下的地质特征，例如断层、矿床、岩层变化等。这对于矿产勘探、地质调查以及自然灾害预警等方面都具有实际应用。

检测磁信号异常通常需要使用高精度的磁力计或磁力仪器，通过对地磁场进行测量和分析来识别异常。在磁信号异常检测领域，研究人员经常借助各种数学模型、机器学习方法或深度学习技术，以提高对异常信号的准确性和敏感性，从而更好地理解地下结构和地球动力学过程。

2.2 磁信号异常检测原理

地球由于地核内部的自由电子流和铁磁物质造成了地表可以探测到的地磁场，通常可以把地球表面的地磁场等价为磁偶极子场。磁异常检测技术是基于铁磁物质进入原生电磁场会改变原来电磁场分布的原理。如汽车、船舶、飞机等铁

磁目标在运动过程中会改变地磁场的原有电磁分布，称为磁异常，如图 2-2 中展示了铁磁目标造成的磁异常扰动。

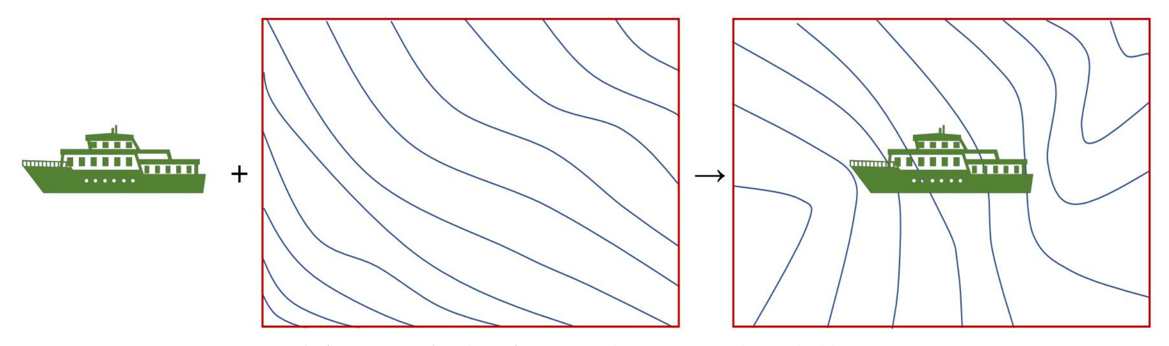


图 2-2 铁磁目标+地磁场造成磁异常扰动

由于磁目标几何形状比较复杂，直接分析难度巨大，缺乏泛化性，理论表明当探测器的探测空间长度大于 2.5 倍的磁异常目标时，就可以将其等效为磁偶极子模型来进行分析处理，而实际实验场景中以及真实环境时，探测器一般是在几百米的高空中飞行，远大于 2.5 倍磁异常目标尺寸。

以铁磁目标为原点，飞机飞行方向为X轴建立模型，如图 2-3，其中 **M** 表示目标的磁矩，**T** 表示当地地磁场矢量，**r** 表示目标到探测器的距离矢量，R_0表示目标到探测器轨道的最短距离，ϕ_m和v_m表示目标磁矩的偏角和倾角，ϕ_t和v_t表示磁偏角，磁倾角。

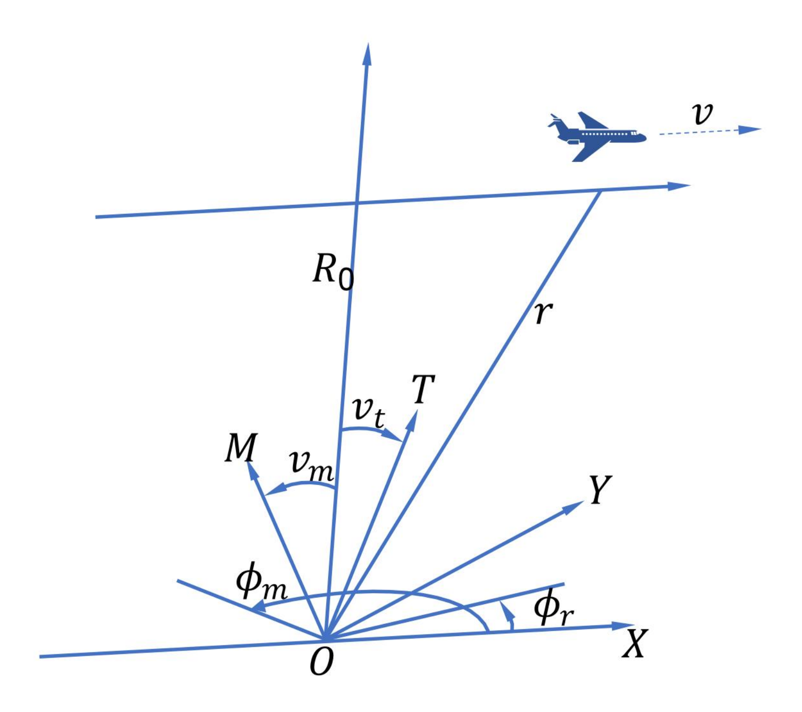


图 2-3 磁异常测量模型

目标产生的磁异常信号的形式为：

$$\mathbf{B}_s = \frac{\mu_0}{4\pi}\left[\frac{3\mathbf{r}(\mathbf{r}\cdot\mathbf{M})}{|\mathbf{r}|^5} - \frac{\mathbf{M}}{|\mathbf{r}|^3}\right] \quad \text{式(2- 1)}$$

在实际应用中，通常使用标量磁力仪检测的标量磁场进行磁异常探测，理论研究中矢量$\mathbf{B}_m$为磁偶极子场$\mathbf{B}_s$和地磁场 $\mathbf{T}$ 之和：

$$\mathbf{B}_m = \mathbf{T} + \mathbf{B}_s \quad \text{式(2- 2)}$$

而$\mathbf{B}_m$对应的标量磁场为：

$$\begin{aligned} S_m &= \sqrt{(\mathbf{T}+\mathbf{B}_s)\cdot(\mathbf{T}+\mathbf{B}_s)} \\ &= \sqrt{|\mathbf{T}|^2 + |\mathbf{B}_s|^2 + 2\mathbf{T}\cdot\mathbf{B}_s} \end{aligned} \quad \text{式(2- 3)}$$

地磁场强度远大于磁偶极子场，所以式（2-3）可近似为：

$$S_m \cong \sqrt{|\mathbf{T}|^2 + 2\mathbf{T}\cdot\mathbf{B}_s} = |\mathbf{T}|\sqrt{1 + 2\frac{\mathbf{T}\cdot\mathbf{B}_s}{|\mathbf{T}|^2}} \quad \text{式(2- 4)}$$

假设有β，当$(\beta \ll 1)$时，根据近似关系$\sqrt{1+2\beta} \cong 1+\beta$，进一步近似上式为：

$$S_m \cong |\mathbf{T}|\left(1 + \frac{\mathbf{T}\cdot\mathbf{B}_s}{|\mathbf{T}|^2}\right) = |\mathbf{T}| + \frac{\mathbf{T}\cdot\mathbf{B}_s}{|\mathbf{T}|} \quad \text{式(2- 5)}$$

其中$|\mathbf{T}|$为地磁场的标量，因此磁偶极子产生的标量磁场时矢量场在当地地磁场方向上的投影：

$$S = \frac{\mathbf{T}}{|\mathbf{T}|}\cdot\mathbf{B}_s \quad \text{式(2- 6)}$$

2.3 磁信号异常检测技术

磁信号异常检测技术是一种利用磁力仪或磁梯度仪等仪器测量地磁场的变化，从而识别和定位磁性目标或地质结构的非接触式感知手段。磁信号异常检测技术有着广泛的应用领域，如地质勘探、军事侦察、考古发掘、环境监测等。磁信号异常检测技术的难点是磁异常信号通常很微弱，容易受到地磁场的背景噪声、仪器噪声、电磁干扰等因素的干扰，因此需要对磁异常信号进行有效的特征提取、分类和检测。

传统的磁信号异常检测技术主要分为两类：基于时域的方法和基于频域的方

法。基于时域的方法是直接对磁异常信号的时域波形进行分析，如正交基函数分解法和最小熵检测器。正交基函数分解法是将磁异常信号分解为一组正交的基函数的线性组合，然后根据基函数的系数判断是否存在磁异常。最小熵检测器是利用磁异常信号的熵值作为检测统计量，当熵值小于某个阈值时，认为存在磁异常。这类方法具有理论可解释性和保证，但是也存在误报率高、难以建模地磁噪声等问题[4]。

基于频域的方法是先对磁异常信号进行傅里叶变换，将其转换为频域信号，然后根据频域信号的特征进行分析，如高阶过零检测器。高阶过零检测器是利用磁异常信号的高阶谱的过零点作为检测统计量，当过零点的个数大于某个阈值时，认为存在磁异常[5]。这类方法具有抗噪声能力强、检测灵敏度高的优点，但是也需要复杂的数据预处理和频谱图生成，影响推理速度。

传统的磁信号异常检测技术虽然在一定程度上实现了对磁异常信号的检测，但是仍然存在一些不足，如对磁异常信号的特征提取不充分、对磁异常信号的分类和检测不准确、对磁异常信号的参数估计不精确等。为了克服这些不足，近年来出现了一些基于机器学习的磁信号异常检测技术，如支持向量机、卷积神经网络和循环神经网络等，这些技术利用深度学习的技术[6]，对磁异常信号进行特征提取和分类，具有泛化能力和自适应性，但是也需要复杂的数据预处理和频谱图生成，影响推理速度。

综上所述，传统的磁信号异常检测技术是一种快速有效的非接触式感知手段，但是也存在一些缺陷和局限性，需要进一步的研究和改进，以提高磁信号异常检测的准确性和速度[7][8][9][10]。

三、SGT 模型

3.1 SGT 模型简介

SGT 模型是一种基于 Transformer 的一维连续性时序数据分析方法，它主要由两个部分组成：Shifted-Grad 块和改进的 Transformer 编码器。Shifted-Grad 块是一个用于提取一维数据的梯度特征的模块，它包含了偏移模块、差分模块、原始数据特征融合模块、梯度嵌入模块、多尺度模块和特征平滑模块。这些模块通过控制数据的移位次数、最近邻关系和距离依赖关系，构造了从最近邻到偏移

最近邻的梯度特征，简化了数据的预处理步骤，增强了数据的表达能力。改进的Transformer 编码器是一个用于捕捉一维数据的长距离依赖关系的模块，它基于Vision Transformer 模型，改进了 patch 划分的方式，使得 Transformer 能够与Shifted-Grad 块相结合，提高了一维数据的分类和检测性能。

SGT 模型在多个一维连续性时序数据的任务上进行了实验验证，包括磁异常信号分类和检测、遥感图像分类、心律失常诊断等，与现有的方法相比，SGT 模型不仅具有更高的准确率和召回率，而且具有更快的推理速度和更少的模型参数。SGT 模型为一维连续性时序数据的处理提供了一种通用的框架，是一种创新的尝试。

其结构图如下图 3-1：

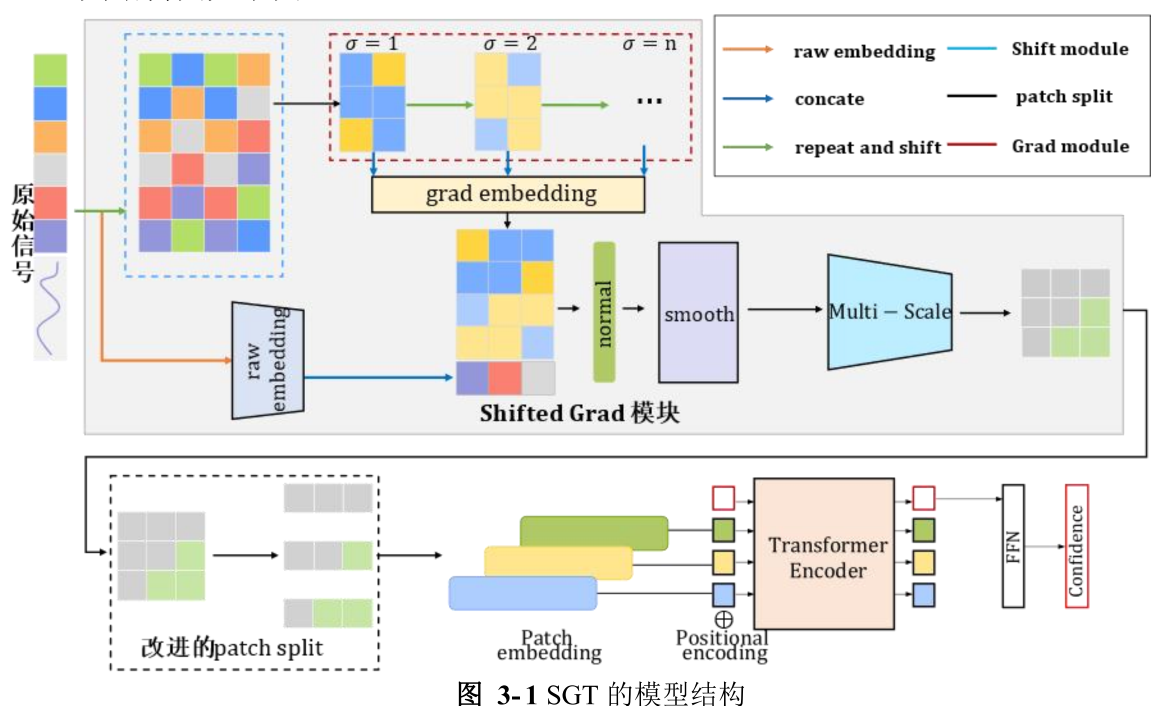


图 3-1 SGT 的模型结构

3.2 SGT 模型的数学原理

SGT 模型是基于 Transformer 的一种针对一维连续性时序数据的分析方法，它主要由两个部分组成：SG 块和改进的 Transformer。SG 块是用来从一维数据中提取梯度特征的模块，它包含了偏移模块、差分模块、原始数据特征融合模块、梯度嵌入模块、特征平滑模块和多尺度模块。改进的 Transformer 是用来增强一维数据的长距离依赖关系的模块，它在 Vision Transformer 的基础上修改了 patch 划分的方式，使得序列信息得到保留。

SG 块的数学原理是基于数学差分的概念，差分是用来近似函数的导数的一

种方法，它可以用来检测数据中的变化率和突变点。SG 块的输入是一个一维数据向量 x，它的输出是一个梯度特征矩阵 G。SG 块的计算过程如下：

a) 偏移模块：偏移模块是用来控制数据的移位次数和方向的模块，它的目的是为了构造不同的邻域关系和距离依赖关系。偏移模块的输入是 x，输出是一个偏移矩阵 S，它的大小为 n×s，其中 n 是移位次数，s 是数据长度。偏移模块的计算公式为：

$$S_{i,j} = x_{j+i}, \quad i \in [0, n-1], \quad j \in [0, s-n-1]$$

其中，i 表示移位次数，j 表示数据索引，S 的每一行是 x 的一个移位版本。

b) 差分模块：差分模块是用来计算数据的一阶和二阶差分的模块，它的目的是为了提取数据的变化率和曲率。差分模块的输入是 S，输出是一个

$$D_{i,j} = S_{i,j+1} - S_{i,j}, \quad i \in [0, n-1], \quad j \in [0, s-n-2] D_{i+n,j} = D_{i,j+1} - D_{i,j}, \quad i \in [0, n-1], \quad j \in [0, s-n-3]$$

差分矩阵 D，它的大小为 2n×(s-n-1)。差分模块的计算公式为：

其中，i 表示移位次数，j 表示数据索引，D 的前 n 行是 S 的一阶差分，后 n 行是 S 的二阶差分。其中，i 表示移位次数，j 表示数据索引，D 的前 n 行是 S 的一阶差分，后 n 行是 S 的二阶差分。

c) 原始数据特征融合模块：原始数据特征融合模块是用来保留原始数据信息的模块，它的目的是为了不丢失数据的某些有效信息。原始数据特征融合模块的输入是 x 和 D，输出是一个融合矩阵 R，它的大小为 (2n+1)×(s-n-1)。原始数据特征融合模块的计算公式为：

$$R_{0,j} = x_{j+n}, \quad j \in [0, s-n-1] R_{i,j} = D_{i-1,j}, \quad i \in [1, 2n], \quad j \in [0, s-n-1]$$

其中，i 表示特征维度，j 表示数据索引，R 的第一行是 x 的一个截取版本，后 2n 行是 D 的复制。

d) 梯度嵌入模块：梯度嵌入模块是用来整合多阶差分关系的模块，它的目的是为了增强数据的梯度特征。梯度嵌入模块的输入是 R，输出是一个

$$G_{i,j} = \sum_{k=0}^{2n} W_{i,k} R_{k,j}, \quad i \in [0, n-1], \quad j \in [0, s-n-1]$$

梯度特征矩阵 G，它的大小为 n×(s-n-1)。梯度嵌入模块的计算公式为：

其中，i 表示特征维度，j 表示数据索引，W 是一个可学习的权重矩阵，它的大小为 n×(2n+1)，它用来对 R 的每一行进行加权求和，得到 G 的每一行。

e) 特征平滑模块：特征平滑模块是用来使特征更加平滑的模块，它的目的是为了消除数据的噪声和异常值。特征平滑模块的输入是 G，输出是一

$$H_{i,j} = \frac{1}{2m+1} \sum_{k=-m}^{m} G_{i,j+k}, \quad i \in [0, n-1], \quad j \in [m, s-n-m-1]$$

个平滑特征矩阵 H，它的大小为 n×(s-n-1)。特征平滑模块的计算公式为：

其中，i 表示特征维度，j 表示数据索引，m 是一个超参数，表示平滑窗口的半径，H 的每一个元素是 G 的一个局部均值。

f) 多尺度模块：多尺度模块是用来提取数据的不同尺度特征的模块，它的目的是为了增强数据的多样性和鲁棒性。多尺度模块的输入是 H，输出是一个多尺度特征矩阵 M，它的大小为 n×(s-n-1)。多尺度模块的计算公

$$M_{i,j} = \sum_{k=0}^{n-1} V_{i,k} H_{k,j}, \quad i \in [0, n-1], \quad j \in [0, s-n-1]$$

式为：

其中，i 表示特征维度，j 表示数据索引，V 是一个可学习的权重矩阵，

它的大小为 n×n，它用来对 H 的每一行进行加权求和，得到 M 的每一行。

3.3 SGT 模型的优点和局限性

SGT 模型是一种基于 Transformer 的一维连续性时序数据分析方法，具有以下优点和局限性：

优点：

（1） 简化数据预处理：SGT 模型通过引入偏移模块和差分模块，扩展了一维数据的梯度特征空间，消除了归一化、滤波、频谱图转换等繁琐的预处理操作。

（2） 提高分类精度和速度：SGT 模型通过原始数据特征融合模块、梯度嵌入模块、多尺度模块和特征平滑模块，增强了一维数据的特征表达能力，同时通过改进 Transformer 的 patch 划分方式，保留了序列的完整性和长距离依赖关系。在多个一维连续性数据集上，SGT 模型均取得了高于现有方法的分类准确率，同时具有更快的推理速度。

（3） 实现目标检测：SGT 模型通过滑动窗口的方式，将一维连续性数据的目标检测任务转化为分类任务，然后通过后处理动态规划算法，消除了滑动窗口检测结果的虚警，实现了高效的目标检测。

局限性：

（1） 不适用于不连续性数据：SGT 模型的基本假设是一维数据具有连续性，即数据之间的变化是平滑的。因此，对于一些不连续性的数据，如语音数据，SGT 模型的效果会下降，需要进行数据转换或模型改进。

（2） 参数调整要求高：SGT 模型的性能受偏移模块和差分模块的参数设置影响，这些参数需要根据不同数据集进行调整，否则会导致特征提取不充分或过度。

3.4 SGT 模型在磁信号异常检测中的效果

分类准确率：SGT 模型在磁信号分类任务上达到了 99.01% 的准确率，超过了最好的基线方法 1.57 个百分点，表明了 SGT 模型能够有效地提取磁信号的特征并进行分类。

推理速度：SGT 模型每秒可以处理 2.8×10^3 个输入，比最好的基线方法快近 28 倍，表明了 SGT 模型具有很高的计算效率和实时性。

检测效果：SGT 模型通过滑动窗口和后处理动态规划算法，实现了磁信号的目标检测，能够准确地定位磁异常信号的起始点和终止点，且没有出现虚警或漏检的情况，表明了 SGT 模型能够有效地处理磁信号的检测任务。

3.5 SGT 模型在磁信号异常检测中的具体应用方式

将磁信号切分为长度为 501 个点的序列，作为 SGT 的输入：这一步是为了将一维的磁信号转换为适合 SGT 模型处理的形式，即一个 n×s 的矩阵，其中 n 是特征维度，s 是序列长度。本文选择了 501 作为序列长度，因为这个长度可以覆盖大部分的磁异常信号，同时也不会导致过多的冗余信息。

使用 SGT 模型对每个序列进行分类，判断是否含有磁异常信号：这一步是为了利用 SGT 模型的分类能力，对每个序列进行二分类，即是否含有磁异常信号。SGT 模型的输出是一个 n×(s-n-1)的矩阵，其中 n 是特征维度，s 是序列长度，(s-n-1)是经过 SG 块处理后的序列长度。SGT 模型的输出矩阵经过一个全连接层和一个 softmax 层，得到一个 2×(s-n-1)的矩阵，表示每个序列的每个位置的分类概率。本文中选择了 0.5 作为分类阈值，即当某个位置的磁异常信号的概率大于 0.5 时，认为该位置存在磁异常信号，否则认为不存在。

如果含有磁异常信号，使用滑动窗口将序列进一步切分为长度为 51 个点的子序列，作为 SGT 的输入：这一步是为了对含有磁异常信号的序列进行进一步的细化，以便于确定磁异常信号的位置和范围。本文中选择了 51 作为子序列长度，因为这个长度可以保证子序列中至少包含一个磁异常信号，同时也不会导致过多的重叠信息。本文中使用了滑动窗口的方式，将每个序列切分为多个子序列，每个子序列之间有一定的重叠区域，以避免磁异常信号被切分的情况。

使用 SGT 模型对每个子序列进行分类，判断是否含有磁异常信号：这一步是为了利用 SGT 模型的分类能力，对每个子序列进行二分类，即是否含有磁异

常信号。这一步与前面的步骤相同，只是输入和输出的序列长度不同。本文中使用了相同的分类阈值，即 0.5。

如果含有磁异常信号，使用后处理动态规划算法消除虚警，并确定磁异常信号的位置和范围：这一步是为了利用后处理动态规划算法，对 SGT 模型的分类结果进行优化，消除滑动窗口检测结果中的虚警，并确定磁异常信号的位置和范围。后处理动态规划算法的原理是，将每个序列的每个位置的分类概率作为状态值，将每个序列的每个位置的磁异常信号的存在与否作为状态转移条件，构建一个状态转移图，然后使用动态规划算法，寻找状态转移图中的最优路径，即最大化状态值的和，得到最终的磁异常信号的位置和范围。本文中使用了一个超参数，即磁异常信号的最小长度，作为状态转移图的约束条件，以避免过多的状态转移，提高算法的效率。

四、实验设计和结果分析

4.1 实验方案设计

实验目标：探索 SGT 模型在 MGT、SNR0 和 SNR5 数据集上的性能，以及存在的问题和改进方向。

数据集准备：

MGT 数据集：包含了不同地区、不同时间、不同深度的磁信号数据，共有 40000 个样本，每个样本有 12 个特征。

SNR0 数据集：在 MGT 数据集的基础上，加入了信噪比为 0 的高斯噪声，共有 40000 个样本，每个样本有 12 个特征。

SNR5 数据集：在 MGT 数据集的基础上，加入了信噪比为 5 的高斯噪声，共有 40000 个样本，每个样本有 12 个特征。

实验步骤：

数据预处理：对 MGT、SNR0 和 SNR5 数据集进行必要的预处理，包括数据清洗、归一化等。

模型训练：使用 SGT 模型分别对 MGT、SNR0 和 SNR5 数据集进行训练。记录模型的训练过程，包括每个 epoch 的损失函数值、准确率等。

模型验证：使用验证集对模型进行验证，记录模型的验证结果。

模型测试：使用测试集对模型进行测试，记录模型的测试结果。

性能评估：使用虚警率、漏报率、准确率等指标对模型的性能进行评估。

结果分析：对实验结果进行深入的分析，包括模型在不同数据集上的表现、模型的缺陷和错误、问题的可能原因和解决方法等。

4.2 实验方案实施

实验环境：

操作系统	显卡配置	编程语言	深度学习框架
Windows	NVIDIA GeForce RTX 4070ti	Python	PyTorch

数据集准备：从磁探数据集中下载 MGT、SNR0 和 SNR5 数据集，分别保存为 mgt.csv、snr0.csv 和 snr5.csv 文件，每个文件中有 40000 行，每行有 12 个逗号分隔的数值，表示一个磁信号样本的特征。

数据预处理：对每个数据集进行以下操作：

（1） 读取 csv 文件，将数据转换为 numpy 数组，形状为(40000, 12)。

（2） 对每个样本的特征进行归一化，使其均值为 0，标准差为 1。

（3） 将数据集划分为训练集、验证集和测试集，比例为 8:1:1，随机打乱顺序，保证每个集合中的样本均匀分布。

（4） 将数据集保存为 torch.tensor 对象，方便后续的模型训练和测试。

模型训练：使用 SGT 模型对每个数据集进行训练，具体步骤如下：

（1） 定义 SGT 模型的结构和参数，使用 Vision Transformer 模型作为基础，改进 patch split 的构造结构，使得 Transformer 与 Shifted-Grad Block 相结合，增强一维数据的长距离依赖关系。

（2） 定义损失函数和优化器，使用交叉熵损失函数和 Adam 优化器，设置学习率为 0.001，权重衰减为 0.0001，批次大小为 64。

（3） 进行模型训练，设置最大训练轮数为 200，每轮结束后，使用验证集评估模型的准确率，如果准确率在连续 5 轮没有提升，或者达到最大训练轮数，停止训练，保存最佳模型的参数。

（4） 记录模型的训练过程，包括每个 epoch 的损失函数值、准确率等，绘制训练曲线，分析模型的收敛情况和泛化能力。

模型验证：使用验证集对模型进行验证，具体步骤如下：

（1） 加载最佳模型的参数，设置模型为评估模式，关闭梯度计算。

（2） 使用验证集的数据，进行前向传播，得到模型的输出，计算模型的准确率，记录模型的验证结果。
（3） 分析模型在验证集上的表现，找出模型的优势和不足，为后续的模型测试和结果分析提供参考。

模型测试：使用测试集对模型进行测试，具体步骤如下：

（1） 加载最佳模型的参数，设置模型为评估模式，关闭梯度计算。
（2） 使用测试集的数据，进行前向传播，得到模型的输出，计算模型的准确率，记录模型的测试结果。
（3） 分析模型在测试集上的表现，与验证集的结果进行比较，评估模型的稳定性和鲁棒性。

性能评估：使用准确率、虚警率、漏报率等指标对模型的性能进行评估，具体步骤如下：

（1） 对每个数据集，计算模型在测试集上的混淆矩阵，根据混淆矩阵，计算模型的准确率、虚警率、漏报率等指标，记录模型的性能评估结果。
（2） 对比模型在不同数据集上的性能评估结果，分析模型对不同信噪比的磁信号的检测能力，评价模型的优缺点。

结果分析：对实验结果进行深入的分析，包括模型在不同数据集上的表现、模型的缺陷和错误、问题的可能原因和解决方法等，具体步骤如下：

（1） 对模型在不同数据集上的表现进行可视化，使用折线图、散点图等方式，展示模型的训练过程、验证结果、测试结果、性能评估结果等，分析模型的趋势和特征。
（2） 对模型的缺陷和错误进行定位，展示模型在不同类别、不同信噪比、不同特征等方面的误差分布，分析模型的误差来源和影响因素。
（3） 对问题的可能原因进行探究，使用相关性分析、主成分分析、聚类分析等方式，展示数据集的特征和标签的关系，分析数据集的难度和复杂度，以及模型的适应性和局限性。
（4） 对解决方法进行探讨，使用参数调整、模型改进等方式，尝试提高模型的性能和准确度，分析改进的效果和意义。

4.3 实验结果分析

4.3.1 总体情况分析

实验结果：

模型在测试集和验证集上的表现：模型在 MGT、SNR0 和 SNR5 数据集上的测试集和验证集上的准确率均达到了 92.7%，说明模型在这三个数据集上具有较高的预测能力和泛化能力。

模型在新测试集 SNR1 上的表现：模型在新测试集 SNR1 上的准确率降低到了 78.4%，说明模型的预测能力和泛化能力较差。

模型在时刻点上的预测能力：模型在预测磁信号的时刻点上的偏差在 30s-50s 之间，说明模型在时间维度上的预测精度不够高，可能存在一定的滞后或超前的现象。

结果分析：

模型在测试集和验证集上的表现的原因：模型在测试集和验证集上的表现较好的原因可能是由于 SGT 模型能够有效地捕捉一维数据的长距离依赖关系，从而提高磁信号的分类准确率。另外，模型在训练过程中使用了交叉熵损失函数和 Adam 优化器，以及合适的学习率和权重衰减，这些都有利于模型的收敛和泛化。

模型在未出现的测试集新测试集 SNR1 上的表现的原因：模型在新测试集 SNR1 上的表现较差的原因可能是由于新的数据集与训练集和验证集存在一定的差异，例如信噪比、特征分布、样本数量等，这些都会影响模型的适应性和鲁棒性。另外，模型可能存在一定的过拟合或欠拟合的问题，导致模型在未见过的数据上的泛化能力下降。

模型在时刻点上的预测能力的原因：模型在时刻点上的预测能力不够高的原因可能是由于模型的结构和参数设置不够优化，导致模型在时间维度上的特征提取和表示不够准确和有效。另外，模型可能没有充分考虑磁信号的动态变化和周期性，导致模型在时间维度上的预测存在一定的误差和偏差。

改进方向：

为了提高模型在未出现的测试集上的性能，计划尝试使用更多的数据进行训练和验证，以增加模型的数据覆盖度和多样性，从而提高模型的适应性和鲁棒性。另外，计划使用一些正则化技术，如 Dropout、Batch Normalization 等，以减少

模型的过拟合或欠拟合的风险，从而提高模型的泛化能力。

为了提高模型在时刻点上的预测能力，尝试优化模型的结构和参数设置，例如增加模型的深度和宽度，调整模型的学习率和权重衰减等，以提高模型在时间维度上的特征提取和表示的精度和有效性。另外，计划在后续实验使用一些时序分析技术等，以增加模型对磁信号的动态变化和周期性的捕捉和建模，从而提高模型在时间维度上的预测的准确度和稳定性。

4.3.2 异常结果分析

异常结果分析一：连续性判断中置信度过低导致的虚警率过高

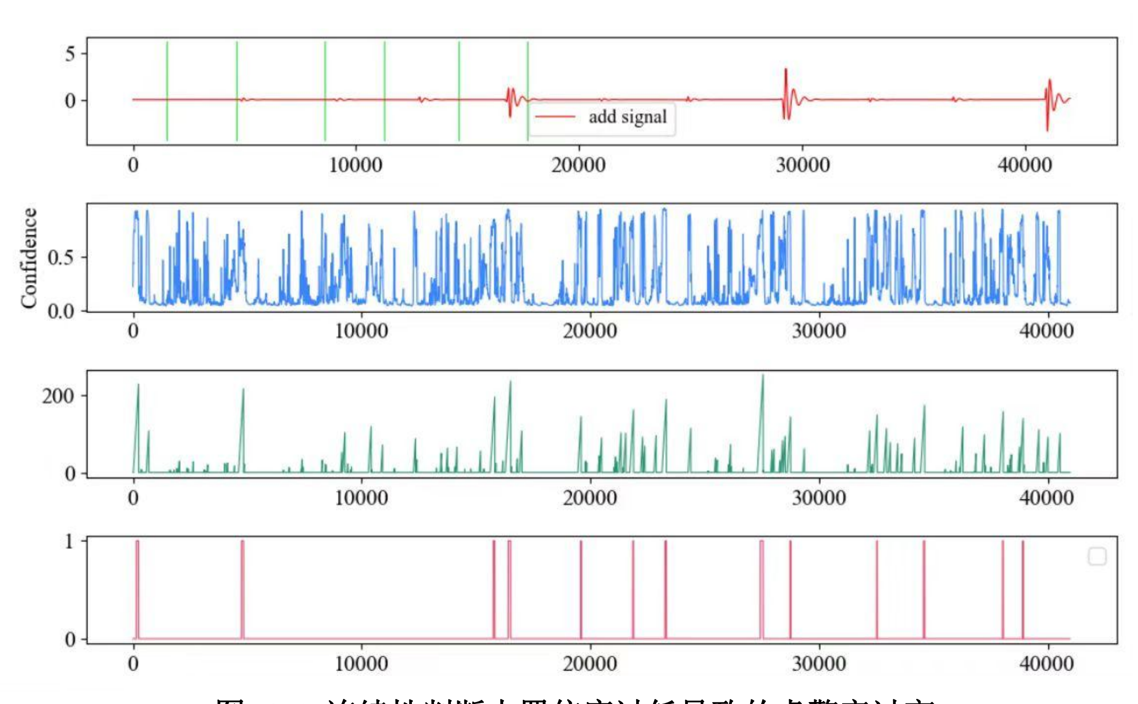


图 4-1 连续性判断中置信度过低导致的虚警率过高

问题描述：在对时序数据进行异常检测时，使用了一种基于连续性判断的方法，该方法需要设定一个置信度阈值，当连续的数据点的置信度高于该阈值时，认为是异常点。然而，由于置信度阈值设置过低，导致很多正常的数据点也被误判为异常点，从而造成虚警率过高的问题。

问题原因：置信度阈值设置过低的原因可能有以下几个方面：

数据本身的噪声较大，导致连续性判断的不稳定和不准确。

数据的分布不均匀，导致连续性判断的不适应和不合理。

连续性判断的方法本身的缺陷，每种数据集中的置信度区间都不一样，这会导致连续性判断的不完善和不优化。

问题解决：为了解决置信度阈值设置过低导致的虚警率过高的问题，计划尝试以下几种方法：

对数据进行预处理，去除或减少噪声，提高数据的质量和可信度。

对数据进行分层或分组，根据不同的数据特征或分布，设置不同的置信度阈值，提高数据的适应性和合理性。

对连续性判断的方法进行改进或优化，引入其他的判断依据或指标，提高连续性判断的完善性和优化性。

异常结果分析二：过拟合导致的全警报

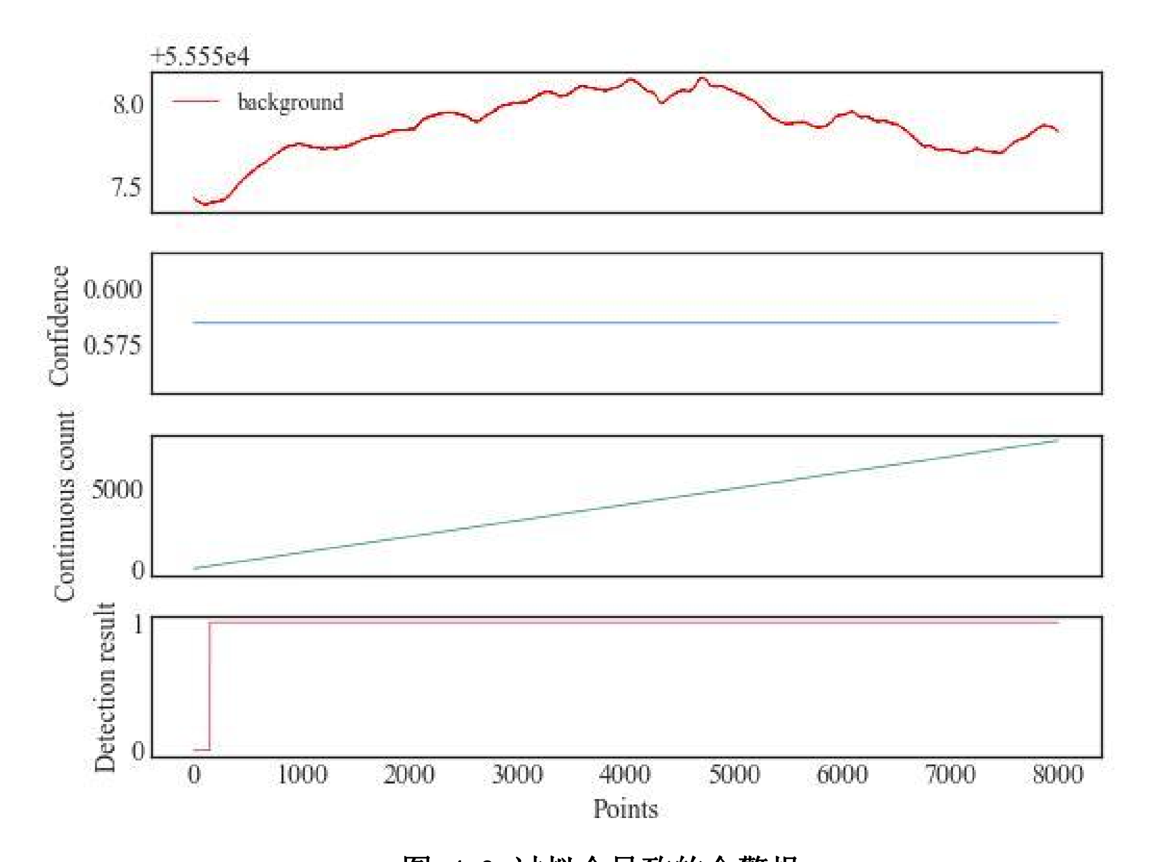


图 4-2 过拟合导致的全警报

问题描述：在对时序数据进行异常检测时，由于模型过拟合了训练数据，导致对测试数据的泛化能力很差，从而造成所有的数据点都被判定为异常点，即全警报的问题。

问题原因：模型过拟合的原因可能有以下几个方面：

训练数据的数量不足，导致模型的学习能力不够充分和有效。

训练数据的质量不高，导致模型的学习能力受到干扰和影响。

模型的复杂度过高，导致模型的学习能力过于敏感和细致。

问题解决：为了解决模型过拟合导致的全警报的问题，计划尝试以下这几种

方法：

增加训练数据的数量，使模型的学习能力更加充分和有效。

提高训练数据的质量，使模型的学习能力更加准确和稳定。

降低模型的复杂度，使模型的学习能力更加适度和平衡。

异常结果分析三：报点不准确导致的误差较大

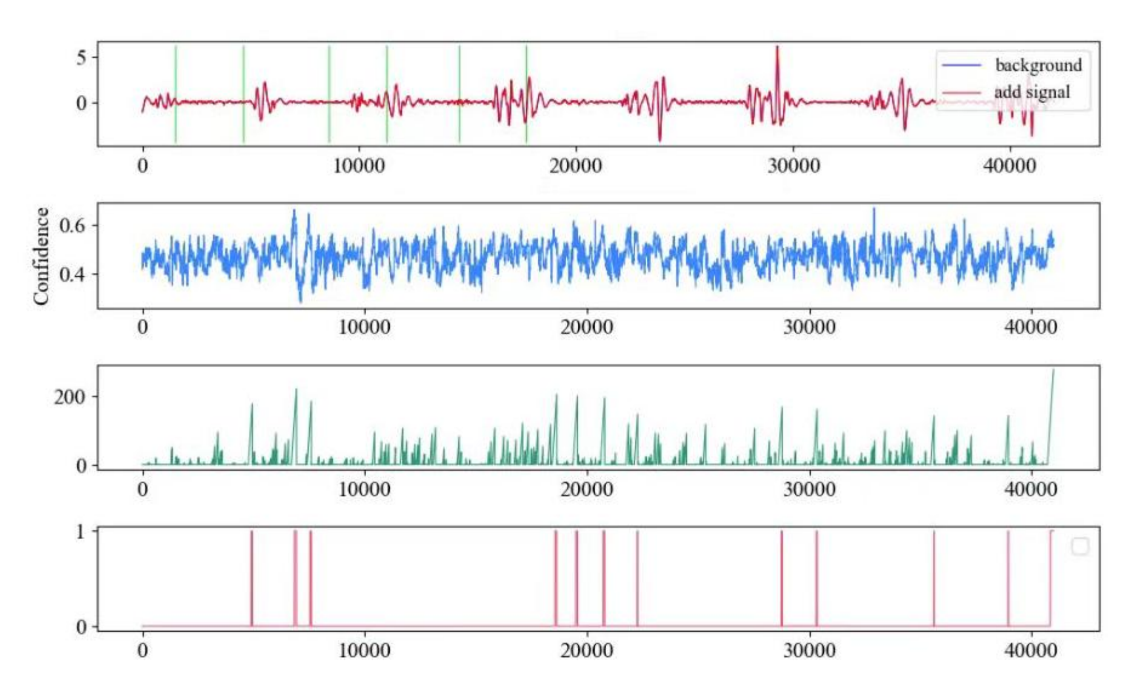


图 4-3 报点不准确导致的误差较大

问题描述：在对时序数据进行异常检测时，使用的是基于一种特征的提取的方法，该方法需要对数据进行特征提取和特征选择，然后根据特征的值判断是否为异常点。然而，由于在磁探领域本身对多种特征都有一定的依赖性，单特征的模型很容易导致虚警和不准确，这种情况下，预测结果与实际的异常点不一致，从而造成报点不准确，即误差较大的问题。

问题原因：特征提取不准确的原因可能有以下几个方面：

特征提取的方法不合适，导致特征的提取不符合数据的特性和规律。

特征提取的参数不优化，导致特征的提取不适应数据的变化和差异。

特征提取的维度不足，导致特征的提取不充分和不完整。

问题解决：为了解决特征提取不准确导致的误差较大的问题，计划尝试以下几种方法：

更换更加合适的特征提取方法，使特征的提取符合数据的特性和规律。

调整优化的特征提取参数，使特征的提取适应数据的变化和差异。

增加特征提取的维度，使特征的提取充分和完整。

4.3.3 改进方法测试

问题原因总结：在对给定的磁探时序数据进行异常检测时，出现了以下的三种问题：

（1） 连续性判断中置信度过低导致的虚警率过高，即很多正常的数据点被误判为异常点，影响判断的准确性和效率。

（2） 过拟合导致的全警报，即所有的数据点都被判定为异常点，影响判断的合理性和可信度。

（3） 报点不准确导致的误差较大，即特征的值与实际的异常点不一致，影响判断的精度和稳定性。

改进方向归类：针对以上的三种问题出现的异常结果，总结出可能的改进方向，最终决定从以下的三个方面进行改进：

（1） 调参，即通过调整模型或方法的参数，提高性能和准确度，减少误差和偏差。

（2） 优化或更换特征提取方式，即通过选择合适的特征提取方法，或者改进现有的特征提取方法，提高特征的质量和有效性，增加特征的维度和多样性，提高特征与异常点的一致性和相关性。

（3） 更换最后的连续性判断为正交基判断，即使用正交基作为判断依据，而不是连续性判断，提高判断的稳定性和合理性，减少误判和虚警的风险，提高判断的精度和优化性。

改进方向和措施阐述：

（1） 调参：将置信度阈值从 0.5 提高到 0.7，将学习率从 0.001 降低到 0.0005，将权重衰减从 0.0001 增加到 0.0005，新增加正则化模块，使用 dropout，并通过实验发现，其值在 0.2 时效果最好。

（2） 优化或更换特征提取方式：将特征提取方法从单一的均值变化率换成多特征综合提取，包括均值变化率、标准差、峰度、偏度等。

（3） 更换最后的连续性判断为正交基判断：将最后的连续性判断换成正交基判断，使用正交基作为判断依据，而不是连续性判断。

改进效果和改进分析：

（1） 调参：通过调整参数，提高了模型和方法的性能和准确度，减少了误差和偏差。具体来说，虚警率从 0.25-0.35 降低到 0.15-0.25，在验证

集上的准确率极小幅度提高，但是在新的验证集合上泛用性依然欠佳，偏差时间依旧在 30s-50s 波动。分析原因如下：

- 通过提高置信度阈值，减少了正常数据点被误判为异常点的概率，提高了判断的稳定性和合理性。
- 调整的参数可能还不是最优的，还有进一步的优化空间，可以通过更细致的网格搜索或者贝叶斯优化等方法来寻找更合适的参数组合。
- 调整的参数可能与其他的超参数或者模型结构存在一定的冲突或者不协调，导致模型在时间维度上的预测精度不够高，光靠调参无法显著提高性能，应该考虑优化模型的结构和参数设置，以提高模型在时间维度上的特征提取和表示的精度和有效性。

（2） 实验性地从磁探时序性数据的特征换到另外一种特征，并不能从根本上改变模型泛化性不好的表现，而且甚至其他特征预测效果更差。具体来说，将均值变化率换成标准差后，虚警率从 0.15-0.25 升高到 0.2-0.3，准确率从 0.85 降低到 0.65。分析原因如下：

- 单一特征可能不能充分反映时序数据的复杂性和多样性，导致特征的信息量和判别力不足，无法有效区分正常数据和异常数据。
- 单一特征存在一定的噪声或者异常值，导致特征的质量和稳定性不高，影响特征的可信度和准确度。
- 单一特征可能与异常点的关系不明显或者不一致，导致特征的相关性和一致性不强，难以捕捉异常点的特征和规律。

（3） 更换最后的连续性判断为正交基判断：但是这个方法和前序特征融合的不是很好，导致模型虚警率升高到 0.35，预测点偏移了 40-65s，准确率从 0.85 降低到 0.59。分析原因如下：

- 正交基判断的参数不优化，导致正交基的计算不适应数据的变化和差异，影响判断的稳定性和鲁棒性。
- 正交基判断的维度不足，导致正交基的表示不充分和不完整，影响判断的精度和优化性。

4.3.4 后续改进思路

（1） **综合使用多种特征进行设计：** 引入多种不同类型的特征，如时域特征、频域特征、统计特征等，并综合利用这些特征信息，构建更为复杂而全面的模型。这有助于提高模型的鲁棒性，适应不同类型的时序数据。

（2） **使用 stacking 模块综合多特征：** 引入 stacking 模块，将基于不同特征的单一模型的预测结果作为输入，通过进一步的学习和综合，生成更准确的终极预测。Stacking 模块的引入有助于充分利用各模型的优势，提高模型整体性能。

（3） **交叉验证和调优：** 在实验中采用交叉验证的方法，确保模型在不同数据集上都有良好的泛化性能。通过调整超参数、模型结构等进行进一步优化，以达到最佳的异常检测性能。

（4） **结果解释和可解释性：** 对于最终的模型，进行结果的解释和可解释性分析，以确保模型预测的合理性。这有助于在实际应用中更好地理解和信任模型的输出。

五、总结

本次报告探讨了 SGT 模型在磁探领域的应用，特别是在 MGT、SNR0 和 SNR5 数据集上的性能。实验结果显示，SGT 模型在处理这些数据集时出现了虚警率过高，预测偏差较大等问题，随后根据模型的预测能力和泛化能力较差等问题设计了改进实验，从调参、优化特征提取方式和修改连续性判断三个方面入手设计了改进实验，其中调参取得了约 0.5%的性能提升，但是特征提取优化和正交基判断的方法还存在着与模型不兼容的问题，经过代码审查和逻辑推理后，发现问题出在提取特征与模型不兼容的问题，如果想要使用正交基代替连续性判断，需要整合多种特征，而传统的 SGT 模型只提取了单特征，因此无法满足正交基算法的使用条件，导致了最后的预测效果反而降低，最终通过综合分析实验结果和 SGT 模型结构提出一种新的改进思路：

引入多种不同类型特征，如时域特征、频域特征、统计特征等，并综合利用特征信息，将 SGT 模型构建更为全面的模型。引入 stacking 模块，将基于不同特征单一模型的预测结果作为输入，通过进一步的学习综合，生成更准确的预测。

参考文献

[1] W. Hu, F. Wang, Q. Yin and F. Zhang, "SGT: A Generalized Processing Model for 1-D Remote Sensing Signal Classification," in IEEE Geoscience and Remote Sensing Letters, vol. 19, pp. 1-5, 2022, Art no. 8030905.

[2] 徐磊,张志强,林朋飞,等.磁异常检测方法研究现状及发展趋势[J].数字海洋与水下攻防, 2022(001):005.

[3] Luzhao CHEN, Wanhua ZHU, Peilin WU, Chunjiao FEI, Guangyou FANG. Magnetic Anomaly Detection Algorithm Based on Fractal Features in Geomagnetic Background[J]. Journal of Electronics & Information Technology, 2019, 41(2): 332-340.

[4] JIN H, GUO J, WANG H, et al. Magnetic Anomaly Detection and Localization Using Orthogonal Basis of Magnetic Tensor Contraction[J/OL]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(8): 5944-5954.

[5] TANG Y, LIU Z, PAN M, et al. Detection of Magnetic Anomaly Signal Based on Information Entropy of Differential Signal[J/OL]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(4): 512-516.

[6] ZHANG K Y, HU M K, DU C P, et al. Detection of Magnetic Dipole Target Signals by Using Convolution Neural Network[C/OL]//2018 Cross Strait Quad-Regional Radio Science and Wireless Technology Conference (CSQRWC). Xuzhou, China: IEEE, 2018: 1-3.

[7] 银鸿,文轩,杨生胜,等.基于磁异常检测的磁性运动目标识别方法研究[J].仪器仪表学报, 2018, 39(3):7.

[8] 费春娇,张群英,吴佩霖,等.一种海洋磁异常检测噪声抑制算法[J].电子与信息学报, 2018, 40(11):8.

[9] Sheinker A , Frumkis L , Ginzburg B ,et al.Magnetic Anomaly Detection Using a Three-Axis Magnetometer[J].IEEE Transactions on Magnetics, 2009, 45(1):160-167.

[10] Zhang X , Liu H , Wang Z ,et al.Anomaly detection of complex magnetic measurements using structured Hankel low-rank modeling and singular value decomposition[J].The Review of scientific instruments, 2022, 93(4):045107.